

## **SIMULACIÓN DE UN CONTROLADOR FOTOVOLTAICO UTILIZANDO ALGORITMO GENETICO**

**Farfán Roberto, Hoyos Daniel**

INENCO (Instituto de Energías No Convencionales) Av. Bolivia 5152 C.P 4400

<http://www.inenco.net> 03874255578, farfanf@inenco.net

CIUNSa (Consejo de investigación UNSa) Av. Bolivia 5152 C.P 4400 <http://www.unsa.edu.ar>

**RESUMEN:** El presente trabajo intenta modelizar el control de un regulador de carga, que mediante técnicas de inteligencia artificial, permita al mismo realizar el aprendizaje de la curva del panel fotovoltaico y la curva de carga de la batería, utilizando un muestreo de las señales del panel y del banco de baterías. De esta forma se logra obtener los puntos pertenecientes a la curva del panel fotovoltaico, el punto de máxima potencia del mismo y la tensión de gaseo de la batería, lo que permite determinar el momento en el que se debe cortar la carga de la batería y de esa forma prolongar su vida útil.

La idea fundamental del aprendizaje evolutivo consiste en considerar a los puntos de los muestreos realizados sobre el sistema, como individuos de una población y aplicar procedimientos de búsqueda que imiten los mecanismos empleados por la evolución. Desde el punto de vista computacional los algoritmos evolutivos pueden considerarse como métodos estocásticos de búsqueda y optimización. Estos algoritmos se pueden utilizar como método de optimización de caja negra, ya que no necesita más conocimiento sobre la función a optimizar que poder obtener una muestra de la misma.

**Palabras claves:** Fotovoltaico, controladores, baterías

### **INTRODUCCIÓN**

Un sistema fotovoltaico autónomo está conformado por un conjunto de paneles fotovoltaicos, un banco de baterías, las cargas que se desean aplicar y finalmente el controlador de carga [Dunlop JP. ,1997]. El trabajo del controlador es regular la corriente que absorbe la batería con el fin de que en ningún momento quede sobrecargada peligrosamente, optimizar la energía captada por los paneles fotovoltaicos y finalmente cuidar que la profundidad de descarga de la batería no sea excesiva para alargar su vida útil [Lorenzo,2006].

Para modelizar un sistema fotovoltaico se debe realizar modelos de controladores, paneles y baterías, como los descriptos en [Murillo, 2003], lo que permite simular el comportamiento del sistema fotovoltaico y probar distintos algoritmos de control. De los distintos métodos de control, se utiliza en este trabajo uno basado en inteligencia artificial [Escolano, 2003], como el método de algoritmo genético. Los algoritmos de control se basan en optimizar el funcionamiento de algunos de los parámetros del sistema, como por ejemplo buscar el punto de máxima potencia de los módulos fotovoltaicos como se detalla en [Battista,(2006)] y [M. G. Molina1, 2006]. A criterio de los autores el componente mas delicado del sistema es la batería, por esta razón es que el método de control propuesto se basa en optimizar el funcionamiento de la misma como ya se propuso en [Hoyos, 2006]. De los distintos modelos de baterías estudiados se aplicó el modelo de Copetti [Copetti, 1993], el cual fue seleccionado por su simplicidad.

El método de algoritmo genético está basado en teorías biológicas aceptadas en la actualidad, en la cual la evolución es el resultado de la interacción entre dos factores: la creación al azar de nueva información genética y la selección no azarosa de los individuos. Cuanto más adaptado está un individuo al entorno en el que vive, mayor es la probabilidad de que sobreviva para tener descendencia. En el proceso de la reproducción, el genotipo de los padres se combina para dar lugar a un nuevo individuo. Además, esporádicamente y debido a errores en la copia del material o a factores externos, se producen mutaciones: variaciones al azar en la que el genotipo queda alterado. Estos nuevos genotipos dan lugar a individuos con características ligeramente distintas a la de los padres. Estos procesos biológicos arriba descriptos son modelados por algoritmos y se le aplicó a un muestreo del sistema que son puntos obtenidos de una simulación de la curva del panel fotovoltaico y la curva de carga de la batería.

### **CONTROLADOR DE CARGA**

El controlador conecta los módulos fotovoltaicos con las baterías y la carga, de forma que estos componentes actúen en forma armónica entre si. Con este fin se diseñó un algoritmo que permite al controlador aprender la curva del panel y de la batería, para que el controlador pueda ubicar los puntos donde el sistema obtenga las máximas prestaciones. Con este fin se utiliza el método de algoritmo genético porque con un conjunto de mediciones de tensión y corriente sobre la batería y el panel fotovoltaico se pueden obtener las curvas características.

## DESCRIPCION DEL ALGORITMO DE APRENDIZAJE EVOLUTIVO

El algoritmo genético utiliza un conjunto de puntos tomados de un muestreo del panel fotovoltaico y de la batería (estos puntos en la simulación se los obtuvo de la ecuación de la curva del panel fotovoltaico y de la curva de carga de la batería). Se utiliza con este fin suponer que el sistema evoluciona en forma similar a los procesos biológicos ocurridos en la naturaleza. Los procesos biológicos de la evolución se modelan desde el punto de vista computacional y de manera simplificada mediante los siguientes pasos.

1-  $P(t)$  representa la población actual, de tamaño  $N$  y  $t$  es el número de generación. La población inicial es el conjunto de medidas obtenidas de la curva del panel y la curva de carga de la batería, a estos puntos lo tomamos como la generación  $t=0$ .

2- La operación EVALUAR es el valor de una función a optimizar. En nuestro caso es la ecuación de carga de la batería que responde al modelo de Copetti y el producto de la tensión por la corriente de los distintos puntos obtenidos del muestreo del panel fotovoltaico para trabajar con la potencia.

3- La operación SELECCIONAR consiste en escoger de manera generalmente probabilística las mejores soluciones, correspondiéndose en la naturaleza con la selección del más apto. Se trabajó con la curva de carga y del panel fotovoltaico de la misma manera, por ejemplo en la curva del panel fotovoltaico a los puntos del muestreo se le asigna una probabilidad que se calculó con la siguiente expresión:  $f_i / \sum f_i$  donde  $f_i$  es un valor de potencia calculado por el producto de la tensión y la corriente obtenidos en el muestreo y  $\sum f_i$  es la suma total de acuerdo a la cantidad de integrantes de la población con la que estamos trabajando (cantidad de puntos del muestreo). Se seleccionaron los puntos que tengan mayor probabilidad ya que el aprendizaje evolutivo debe converger al punto de máxima potencia.

4- CRUZAR Y MUTAR son los operadores de búsqueda del algoritmo y consisten en la combinación aleatoria de dos o más soluciones y a la variación aleatoria de la misma. Por ejemplo la combinación de dos números obtenidos del muestreo seleccionados para su evolución. Estos generan una nueva población  $P'(t)$  de un tamaño determinado  $\lambda$ , que deberá reemplazar a la población inicial (muestreo), obteniendo así la primera generación  $t=1$  o población uno y esto se repetirá  $n$  veces hasta encontrar la solución buscada.

## APRENDIZAJE DE LA CURVA DEL PANEL Y BUSQUEDA DEL PUNTO DE MÁXIMA POTENCIA

El problema que tiene generalmente una instalación fotovoltaica es la predicción del comportamiento eléctrico de un generador fotovoltaico. La curva característica IV de una célula solar puede expresarse con suficiente aproximación con la siguiente expresión;

$$I = I_1 - I_0 \left[ \exp \left( \frac{V + I R_s}{n V_t} \right) - 1 \right] - (V + I R_s) / R_p \quad (1)$$

$I_1$ ; Corriente fotogenerada.

$I_0$ ; Corriente de saturación inversa del diodo.

$V_t$ ;  $KT/e$ , voltaje térmico.

$T$ ; temperatura en grados kelvin.

$R_s$ ; resistencia serie.

$R_p$ ; resistencia paralelo.

$n$ ; factor de idealidad del diodo. ( $n=1$  para las graficas de la simulación)

Para el caso de un panel fotovoltaico sus características eléctricas dependerán fundamentalmente del número de células en serie y en paralelo que posea. La simulación del aprendizaje evolutivo se realizó sobre la curva del panel que responde a la ecuación 1. Se comenzó tomando una población inicial o muestreo  $P(t)$  de 80 puntos de la curva del panel la cual podemos esquematizar en la curva de I-V y P-V del modulo fotovoltaico como lo indica la figura 1. El muestreo son puntos que se obtuvieron de la curva que responde a la ecuación 1 y sirve como población inicial para la simulación.

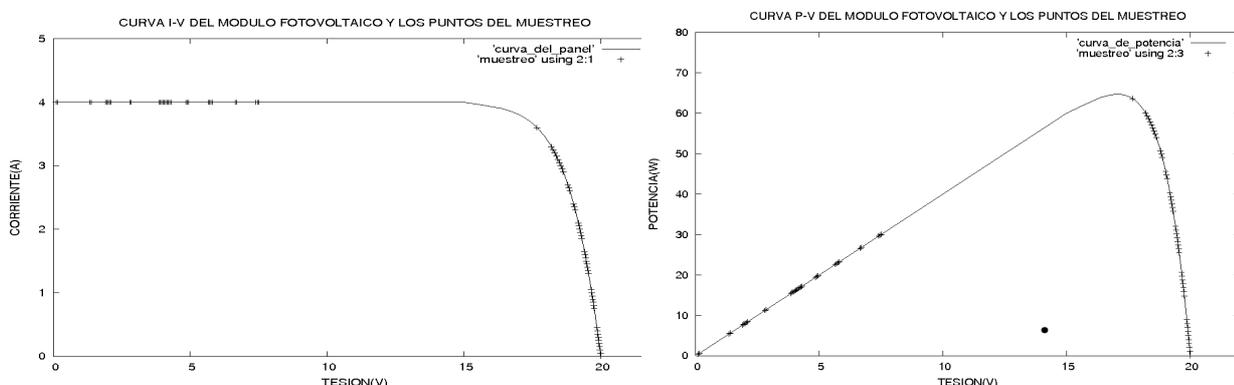


Fig1. Curva I-V y P-V del modulo fotovoltaico conteo del muestreo tomado como la primera población.

Se transformó los números decimales obtenidos del muestreo a enteros y después de un ciclo del algoritmo de enteros a decimales, lo cual permite un trabajo más cómodo en las distintas etapas de la evolución.

La operación EVALUAR representa el valor de una función a optimizar, en el caso del panel se eligió el producto de la tensión por la corriente de los distintos puntos obtenidos del muestreo. Esta decisión se tomo después de simular la evolución del muestreo, conociendo la función del panel fotovoltaico dada por la ecuación uno y otra no conociendo dicha función utilizando una función evaluar que sea el producto de la tensión por la corriente. En ambas simulaciones se logró el correcto aprendizaje de la curva llegando al punto de máxima potencia.

La operación SELECCIÓN permite asignar a cada valor de potencia, obtenido por la población inicial, una probabilidad. La asignación de esta probabilidad ya se describió en el punto tres en la descripción del algoritmo de control. La operación selección elige probabilísticamente las mejores soluciones que en este caso son aquellos valores que tengan probabilidad más alta ya que uno de los fines del aprendizaje evolutivo es que los puntos converjan al punto de máxima potencia. En los algoritmos genéticos este tipo de selección se realiza cuando se busca el máximo de una función. Los valores que estén mas cerca del punto de máxima potencia, dados por el muestreo, son los que tendrán mayor probabilidad de ser seleccionados para la evolución.

La operación de CRUCE se realiza una vez seleccionados los individuos. Esta operación es probabilística y en nuestra simulación se hace por pares. Por lo tanto se debe definir una probabilidad de cruce **pc** que me determina si dado un par de individuos de la población (o sea puntos que inicialmente son del muestreo) se efectúa realmente el cruce o no.

La operación MUTACIÓN se realiza probabilísticamente y se define una probabilidad **pm** para ver si cada uno de los números que componen la, población debe mutar. El último paso de un ciclo del algoritmo es reemplazar la nueva población por la que estaba inicialmente (muestreo) y se comienza de nuevo con otro ciclo hasta encontrar el punto de máxima potencia del panel fotovoltaico.

En este esquema se ve un ejemplo de como trabaja el algoritmo evolutivo en sus distintas etapas;

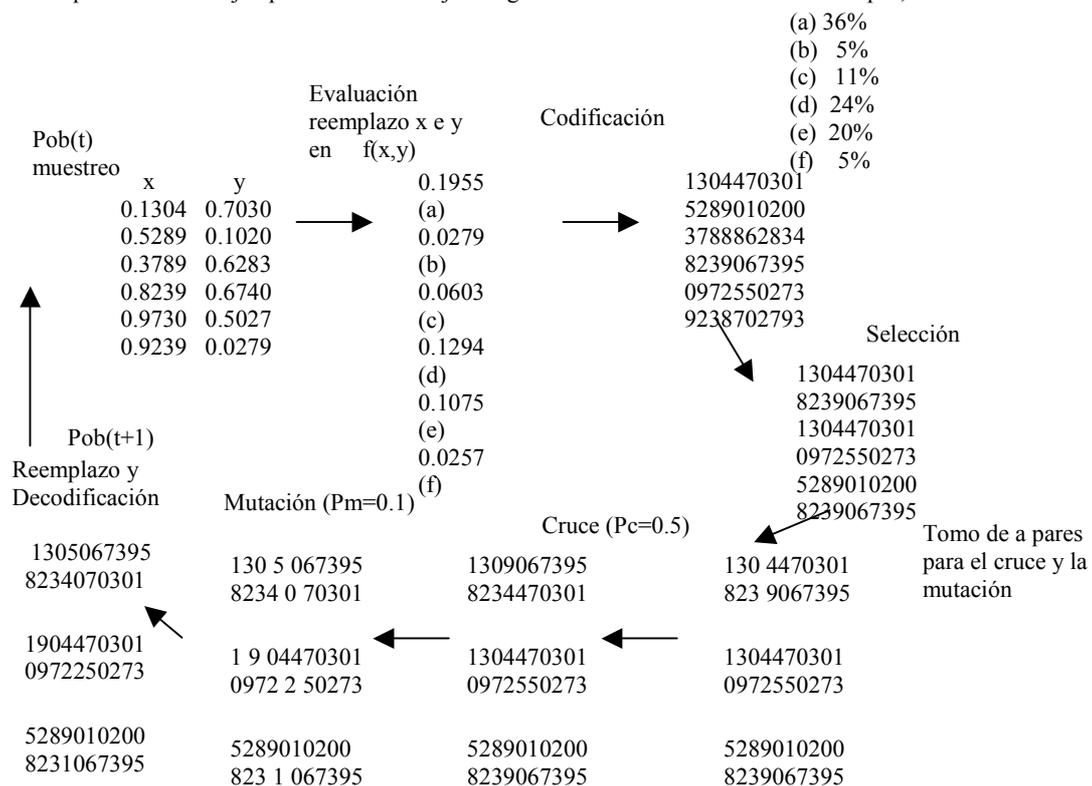


Figura 2. En este esquema se muestra como el muestreo (población inicial) evoluciona en el algoritmo en una función  $f(x,y)$  definida en un dominio  $[0,1]$  para  $x$  y  $[0,1]$  para  $y$ .

Las probabilidades de cruce y mutación se eligieron después de correr distintas simulaciones y verificar que los puntos tomados en un muestreo al azar convergen al punto de máxima potencia. En el muestreo existen dos valores claves que deben tomarse, la corriente de corto circuito y la tensión de circuito abierto. Estos dos valores determinan el dominio de trabajo del algoritmo ya que algún individuo de la población al mutar o cruzarse con otro puede generar individuos que no pertenezcan al dominio de trabajo definido y de esta forma el algoritmo no genera los puntos pertenecientes a la curva del panel ni converge al punto de máxima potencia. En la simulación del algoritmo, esquematizada en la figura 3, vemos que los puntos tomados de un muestreo llamado población 0 (esta es la población inicial), y se observa que al evolucionar por primera vez

estos puntos, se generan una población 1 concentrados en la cercanía del punto de máxima potencia. En las evoluciones siguientes, se generaran distintas poblaciones en los que se observa claramente que convergen al punto de máxima potencia.

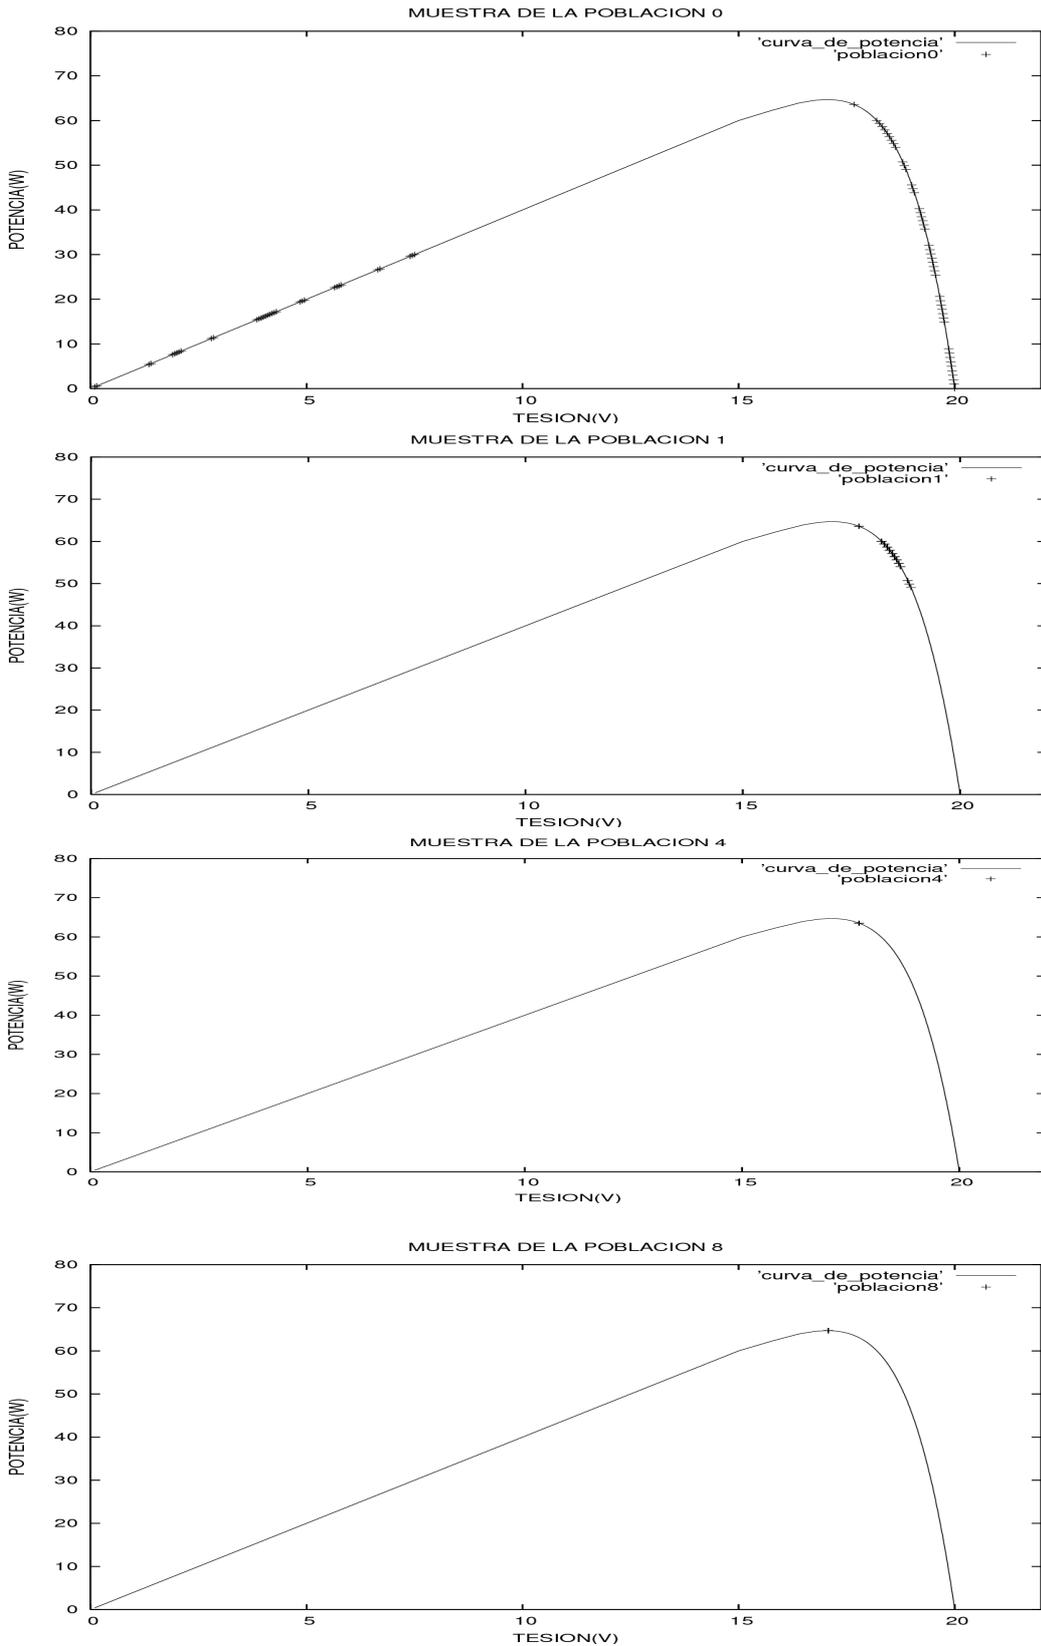


Figura 3. Resultados de la evolución del algoritmo y la búsqueda del punto de máxima potencia

El problema principal que surge de este muestreo es que se realizó sobre toda la curva, lo cual se verificó en otras simulaciones, que al tomar puntos de la región donde la pendiente de la curva es positiva y está cerca del punto de máxima potencia, tiene muchas probabilidades de evolucionar y que en el cruce o mutación se genere un número que no pertenezca al

dominio de trabajo. De esta forma la evolución no genera los puntos pertenecientes a la curva del panel y no converge al punto de máxima potencia o puede converger a un punto erróneo que no pertenezca a la curva.

Lo más conveniente al realizar el muestreo es que se debe realizar en la parte donde las pendientes de la curva de potencia es negativa (desde el punto de máxima potencia hasta el circuito abierto en la curva IV) lo cual genera en las sucesivas evoluciones de la población, puntos pertenecientes a la curva del panel asegurando una convergencia segura hacia el punto de máxima potencia sin correr el riesgo de salir del dominio de trabajo. Con el muestreo de 80 puntos o individuos el aprendizaje evolutivo de la curva del panel y la obtención del punto de máxima potencia se realiza con 8 o 9 iteraciones, aproximadamente con diez generaciones  $t=10$ . Un muestreo de 80 puntos de la curva seguramente no es simple de conseguir en la práctica y por lo tanto se realizó simulaciones con muestreos de cinco puntos de la curva para que evolucione, aprenda la curva y obtenga el punto de máxima potencia. Al cambiar el muestreo de 80 a 5 puntos, se necesitó para completar el aprendizaje evolutivo aproximadamente de 20 a 25 iteraciones o sea 26 generaciones  $t=26$ . Se pudo observar que cuando el muestreo era más pequeño (población inicial mínima), se necesitan mas generaciones para completar el trabajo de aprender la curva.

## DESCRIPCION DEL MODELO DE BATERIA

La naturaleza de la radiación solar es variable en el tiempo y consecuencia de esto es que son muchos los momentos en los que la potencia eléctrica que puede entregar un generador fotovoltaico difiere, por exceso o por defecto, de una determinada demanda. El correcto abastecimiento energético de la aplicación exige, poder almacenar energía cuando la producción fotovoltaica excede a la demanda para utilizarla en la situación contraria, por ello se utilizan en un sistema fotovoltaico acumuladores electroquímicos.

El proceso de carga de una batería supone transformación en  $PbO_2$  y  $Pb$  del  $PbSO_4$  de las placas con liberación de ácido al electrolito, mediante una corriente que entra en la batería por su ánodo. Al aproximarse al final de la carga, la materia activa comienza a escasear y parte de la corriente se emplea no en producir la reacción característica de la batería, sino en descomponer el agua, en oxígeno e hidrógeno que se liberan del electrolito en forma de gases ( $O_2$  en el polo positivo y  $H_2$  en el polo negativo). Este fenómeno se conoce con el nombre de gasificación o gaseo y tiene consecuencias negativas y positivas.

Cuando el gaseo llega a ser muy intenso, genera pérdida de materia activa por el arrastre que producen las burbujas del gas. El gaseo es positivo cuando produce la homogenización del electrolito, ya que el movimiento de las burbujas colabora muy eficazmente para evitar la estratificación del electrolito.

La figura 3 muestra la curva de la tensión de carga de un elemento de la batería en función del tiempo, donde se encuentra la tensión de gaseo y la tensión de final de carga.

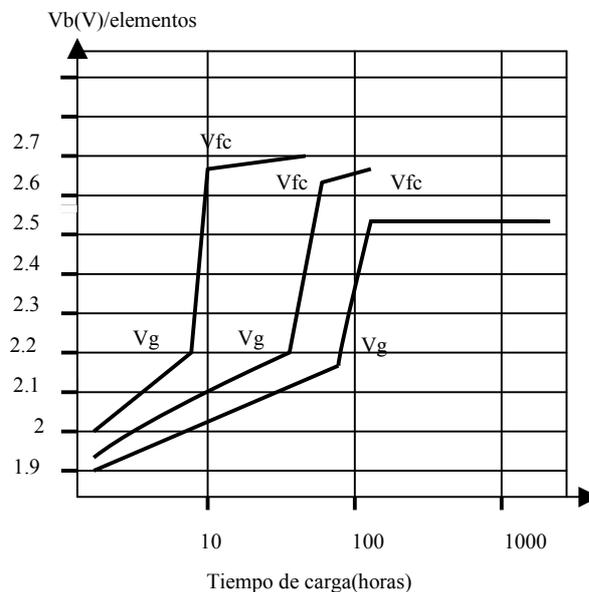


Figura 3. Curva de la tensión en bornes de una celda de una batería durante un proceso de carga a corriente constante en función del tiempo

El correcto modelado de las baterías es fundamental para predecir el comportamiento en las condiciones de funcionamiento más adversas y decidir el modo de carga / descarga para alargar su vida útil. El modelo de la batería utilizada es el de Copetti normalizado, el cual permite tener en cuenta los parámetros más relevantes de la batería, lo que permitió un modelo adecuado.

La ecuación normalizada de la tensión de descarga esta dada por:

$$V_d = (2.085 - 0.12(1 - SOC)) - I/C10(4/(1 + 11.3) + 0.27/SOC1.2 + 0.02)(1 - 0.007\Delta T) \quad (2)$$

Donde el SOC es el estado de carga de una batería y puede tener valores entre cero y uno. El SOC debe calcularse en cada instante con la siguiente relación:

$$\text{SOC} = Q/C \quad (3)$$

Q; Cantidad de carga que en ese instante almacena la batería.  
C; Capacidad correspondiente al régimen de trabajo.

La Capacidad correspondiente al régimen de trabajo se la obtendrá con la siguiente expresión;

$$C/C10 = 1.67 / (1 + 0.67(I/I10)) (1 + 0.005\Delta T) \quad (4)$$

En el proceso de sobrecarga, el valor de la tensión de inicio del gaseo  $V_g$  esta dada por;

$$V_g = (2.24 + 1.97 \ln(1 + I/C10)) (1 - 0.002\Delta T) \quad (5)$$

La tensión final de carga  $V_{fc}$  esta dada por;

$$V_{fc} = (2.45 + 2.011 \ln(1 + I/C10)) (1 - 0.002\Delta T) \quad (6)$$

La tensión de la batería se representa por la siguiente expresión;

$$V_b = V_g + (V_{fc} - V_g) (1 - \exp((Q_{sc} - 0.95C) / I T_{sc})) \quad (7)$$

Donde  $Q_{sc}$  es la cantidad de carga que entra a la batería y  $T_{sc}$  es la constante de tiempo que se determina del modo siguiente:

$$T_{sc} = 17.3 / (1 + 852(I/C10)^{1.67}) \quad (8)$$

#### APRENDIZAJE DE LA CURVA DE CARGA Y BÚSQUEDA DE LA TENSIÓN DE GASEO

Con las simulaciones se obtuvieron las gráficas de los distintos parámetros de la batería a distintas temperaturas, como la capacidad de acuerdo al régimen de descarga como indica la figura 4.

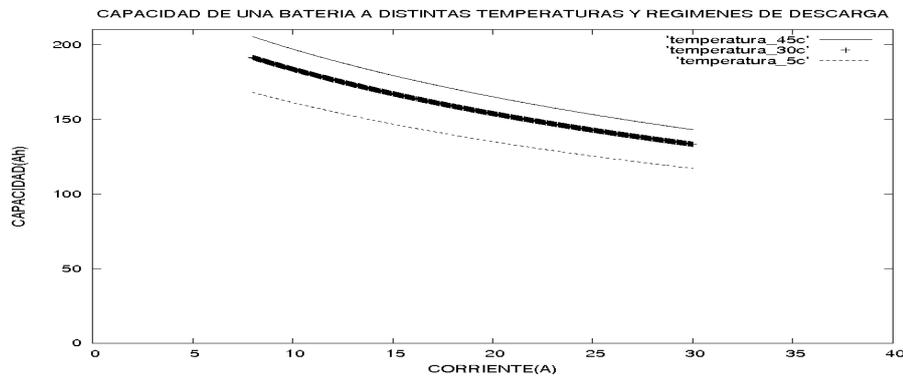


Figura 4. Evaluación de capacidad a distintas temperaturas y regímenes de descarga

La variación de la tensión final de carga con la corriente a distintas temperaturas se puede observar en la figura 5.

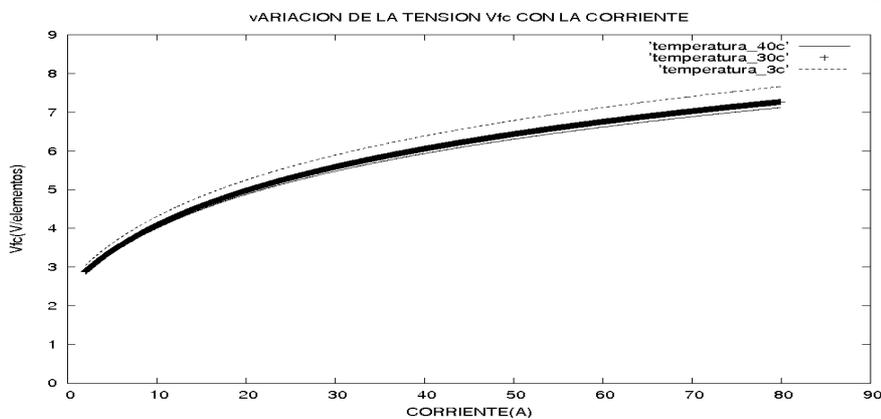
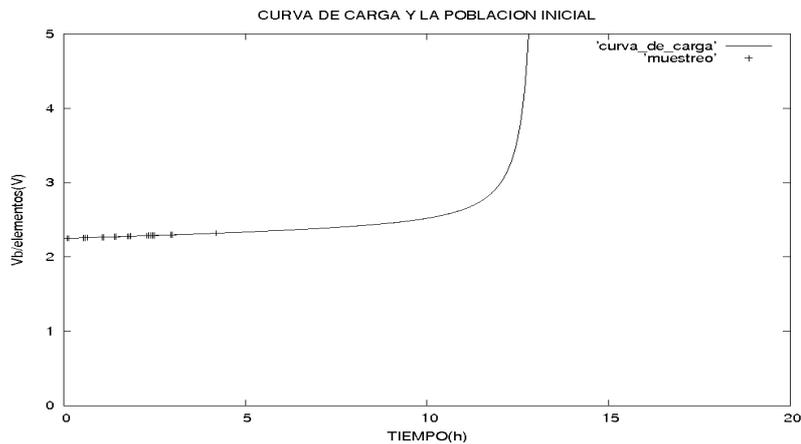


Figura 5. Variación de la tensión final de carga con la corriente y la temperatura

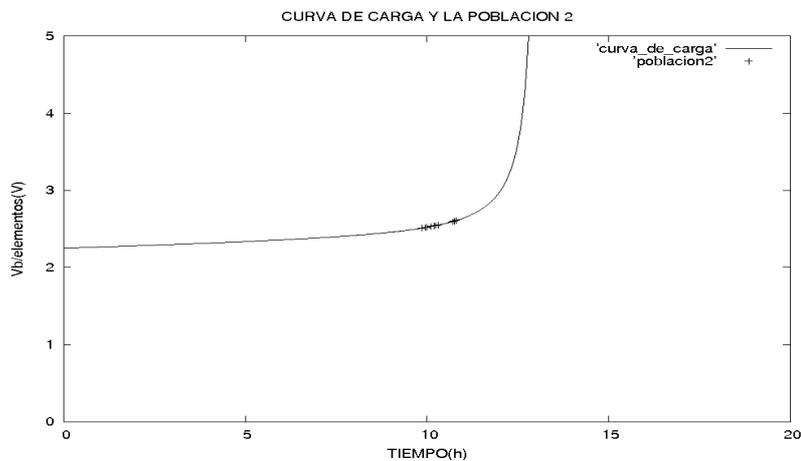
El controlador, cuando la batería se encuentre descargada, mediante un muestreo de la tensión en el proceso de carga, implementa el algoritmo evolutivo que permite la evolución de los puntos del muestreo. De esta forma se logra el aprendizaje de la curva de carga de la batería topándose en la misma con el punto correspondiente a la tensión de gaseo y por lo tanto sabemos cual es la carga que se necesita en ese momento para aumentar el rendimiento del sistema fotovoltaico.

El algoritmo evolutivo trabaja el muestreo de la curva de carga de la batería igual que el muestreo del panel fotovoltaico. La curva de carga de la batería comienza a crecer a medida que se le suministra corriente, por lo tanto se asigna una probabilidad a cada punto del muestreo y se seleccionará para la evolución aquellos que tengan probabilidad más grande ya que se intenta buscar un máximo para que el aprendizaje sea sobre toda la curva de carga.

La figura 6 y la figura 7 muestran la simulación del aprendizaje de la curva de carga mediante un muestreo aplicando el algoritmo del controlador, obteniendo puntos pertenecientes a la curva de carga.



**Figura 6:** Curva de carga de la batería población inicial



**Figura 7:** Curva de carga de la batería población dos

## DESCRIPCIÓN DEL CONTROLADOR

De acuerdo a lo anteriormente expuesto el algoritmo de control propuesto analiza el panel obteniendo la curva VI y el punto de máxima potencia de los paneles de la instalación, también analiza la batería y obtiene la curva de carga de la misma determinando la tensión de gaseo. Este algoritmo prevé encontrar la tensión de gaseo analizando el cambio de pendiente de la curva de carga. Al encontrar la tensión de gaseo y conociendo la corriente que se le proporciona a la batería, el controlador tendrá la información suficiente para conocer las características fundamentales de la batería que responde al modelo de Copetti y realizar el aprendizaje descrito.

El controlador divide la etapa de carga de la batería en tres partes: en la primera etapa la batería realiza una carga hasta un 75% de la carga total que estará en función de la tensión de gaseo ya determinada y de esta forma determina la cantidad de energía que debe proporcionarle para que su carga sea completa. La segunda etapa consiste en una carga lenta de la batería regulando la corriente hasta alcanzar la tensión de gaseo que dependerá también de la temperatura. La tercera etapa se denomina flotación y permite mantener la carga de la batería.

Gracias al conocimiento de la curva VI de los paneles fotovoltaico (punto de máxima potencia) y de la curva de carga de la batería, con un conversor DC-DC se transforma la tensión que el panel tiene en el punto de máxima potencia en la tensión de la batería. Esto permite una carga sin llegar a la tensión de gaseo respetando los pasos descritos anteriormente. Este conversor DC-DC debe poder ser regulado. Las curvas características del panel y de la batería dependen de muchos factores (corriente, temperatura, tensión, etc.). Por lo tanto la medición de las corrientes y tensiones de los paneles fotovoltaicos y las baterías debe realizarse continuamente para determinar las distintas curvas características. Este algoritmo fue simulado y funciona aceptablemente. Actualmente, se está desarrollando el hardware para probar el sistema. .

## CONCLUSIÓN

Del análisis realizado se puede concluir que midiendo las características del panel y realizando la medición de la tensión y la corriente de carga de las baterías, se pueden determinar: los parámetros de funcionamiento de la batería y de los paneles fotovoltaicos.

En la batería se determina:

1. capacidad de carga en 10 horas
2. tensión de gaseo
3. tensión final de carga
4. Curva característica de la carga

En el módulo fotovoltaico se determina:

1. Curva de Panel
2. Punto de máxima potencia

A partir de estos datos el controlador puede actuar en forma eficiente. Experimentalmente se verificó el algoritmo sobre un panel fotovoltaico y se está comenzando a medir baterías para verificar los resultados obtenidos por la simulación. Se está diseñando el controlador utilizando un microcontrolador PIC18F452, que trabaja en lenguaje C.

## REFERENCIAS

- Del Carmen Alonso García (2000), Fundamentos Dimensionado y Aplicaciones de la energía solar fotovoltaica. Electricidad Solar Fotovoltaica (1994), Lorenzo.
- Escolano Ruiz F., Miguel Angel Cazorla Quevedo (2003), Inteligencia Artificial, Thompson.
- Dunlop JP., (1997) Batteries and Charge Control in Stand-Alone Photovoltaic Systems Fundamentals and Application, Sandia National Laboratories
- Murillo Daniel (2003), Modelado y Análisis de sistemas fotovoltaicos, Universitat Politècnica de Catalunya.
- Copetti JB, **Chenlo** F, Lorenzo E.(1993) A general **battery model** for PV system simulation. Progress in Photovoltaics: Research and Applications; 1: 283–292.
- J. García Clúa, R. J. Mantz, H. De Battista, (2006), Alternativa de control por modo deslizante para seguimiento robusto de la máxima potencia fotovoltaica. Avances en Energías Renovables y Ambiente Vol 10 ISSN 0329-5184
- G. Molina1, D. H. Pontoriero (2006) Seguidor del punto de máxima potencia para sistemas fotovoltaicos basados en convertidor cc/cc elevador de tensión. Avances en Energías Renovables y Ambiente Vol 10 ISSN 0329-5184
- Hoyos D., (2006) Propuesta de controlador con lógica difusa para sistema eólico. Avances en Energías Renovables y Ambiente Vol 10 ISSN 0329-5184

## ABSTRACT

This paper studies the application of a genetic algorithm to control an stand alone photovoltaics system. The algorithm detect the VI curve from the photovoltaics array using a very simple method and the charge curve from the battery. Then the controller optimize the system.